

Research on Topographic Map Updating

Ivana Javorović

Remote Sensing Laboratory, Ilica 242, 10000 Zagreb, Croatia

Miljenko Lapaine

University of Zagreb, Faculty of Geodesy, Kačićeva 26, 10000 Zagreb, Croatia

Ivana Lampek-Pavčnik

GISDATA d.o.o., Baštijanova 52a, 10000 Zagreb, Croatia

ABSTRACT. *The investigation of interpretability of panchromatic satellite image IRS-1C integrated with multispectral Landsat TM image with the purpose of updating the topographic map sheet at the scale of 1:25 000 has been described. The geocoding of source map was based on trigonometric points of the map sheet. Satellite images were geocoded using control points selected from the map. The contents of map have been vectorized and topographic database designed. The digital image processing improved the interpretability of images. Then, the vectorization of new contents was made. The change detection of the forest and water area was defined by using unsupervised classification of spatial and spectral merged images. Verification of the results was made using corresponding aerial photographs. Although this methodology could not insure the complete updating of topographic map at the scale of 1:25 000, the database has been updated with huge amount of data. Erdas Imagine 8.3. software was used.*

Key words: *topographic map updating, satellite images*

1. INTRODUCTION

The system of satellite data gathering about the earth's surface, as one of the remote sensing branches, has become in the recent decades an inevitable area in solving various professional and scientific problems arising from the research of the Earth.

Referring to the obsolescence of topographic map contents of the Republic of Croatia being even more than 25 years old for some areas, the basic idea of this work is to present the interpretability of satellite images to be used in topographic map updating. There has been chosen the area of the topographic map sheet at the scale of 1:25 000 and made in 1975. The fundamental source of the new content were the panchromatic satellite image IRS-1C from 1997 with the spatial resolution of 5.8 m and the multispectral image Landsat TM from 1994. The source has been geocoded, the original images have been spatially and spectrally merged, the map contents have been vectorized and the database created, the interpretation and classification of satellite images have been done in order to detect the changes, and the new state has been vectorized, i.e. the database updated, and finally the digital cartographic presentation carried out. The software Erdas Imagine 8.3 has been used for that purpose.

Istraživanje osuvremenjivanja topografskih karata

Ivana Javorović

Laboratorij za daljinska istraživanja, Ilica 242, 10 000 Zagreb

Miljenko Lapaine

Geodetski fakultet Sveučilišta u Zagrebu, Kačićeva 26, 10 000 Zagreb

Ivana Lampek-Pavčnik

GISDATA d.o.o., Baštijanova 52a, 10 000 Zagreb

SAŽETAK. U radu se istražuje interpretabilnost pankromatskoga satelitskog snimka IRS-1C integriranoga s multispektralnim snimkom Landsat TM u svrhu ispitivanja mogućnosti osuvremenjivanja lista topografske karte mjerila 1:25 000. Geokodiranje izvorne karte izvedeno je na temelju koordinata trigonometrijskih točaka lista karte. Satelitski snimci geokodirani su s pomoću kontrolnih točaka preuzetih s karte. Vektoriziran je sadržaj karte i kreirana topografska baza podataka. Digitalnom obradom snimaka poboljšana je njihova interpretabilnost, a zatim provedena vektorizacija novonastalog stanja. Detekcija promjena šumskog i vodenog područja definirana je na temelju nadzirane klasifikacije integriranoga (prostorno i spektralno spojenoga) snimka. Provjera dobivenih rezultata izvedena je s pomoću odgovarajućih aerofotogrametrijskih snimaka. Iako navedenom metodologijom nije u potpunosti osigurano osuvremenjivanje topografskih karata mjerila 1:25 000, baza je upotpunjena velikom količinom podataka. Rad je izveden s pomoću softvera Erdas Imagine 8.3.

Ključne riječi: osuvremenjivanje topografskih karata, satelitski snimci

1. UVOD

Sustav satelitskog prikupljanja podataka o površini Zemlje, kao jedna od grana daljinskih istraživanja, postao je posljednjih desetljeća nezaobilazno područje rješavanja raznih stručnih i znanstvenih problema u proučavanju Zemlje.

S obzirom na zastarjelost sadržaja topografskih karata Republike Hrvatske, koja je za neka područja 25 i više godina, osnovna je zamisao ovoga rada pokazati interpretabilnost satelitskih snimaka u svrhu osuvremenjivanja topografske karte. Izabrano je područje lista topografske karte u mjerilu 1:25 000 iz 1975. godine. Temeljni je izvornik novoga sadržaja pankromatski satelitski snimak IRS-1C iz 1997. godine, prostorne rezolucije 5,8 m, i multispektralni snimak Landsat TM iz 1994. godine. U radu je izvedeno geokodiranje izvornika, prostorno i spektralno spajanje izvornih snimaka, vektorizacija sadržaja karte i kreiranje baze podataka, interpretacija i klasifikacija satelitskih snimaka radi detekcije promjena te vektorizacija novonastalog stanja, tj. osuvremenjivanje baze podataka, izvedba digitalnoga kartografskog prikaza. Rad je izveden s pomoću softvera Erdas Imagine 8.3.

2. METHODOLOGY

2.1. Geocoding

The original topographic map sheet TK25 Osijek(326)-4-3 has been scanned with the resolution of 600 dpi. Before geocoding the resolution has been reduced to 400 dpi because of an extensive data amount. The procedure of geocoding the topographic map sheet has been carried out on the basis of trigonometric points as control points.

In order to make it possible for satellite image to be used in the production or updating of maps, it is also indispensable to geocode them, i.e. to restructure the image elements so that they are in accordance with the position in a specific map projection. There are parameter and non-parameter transformations used for the transformation of points between map projection and satellite image, depending on whether the sensor parameters are determined in the transformation procedure or not. The most frequent solution is the non-parameter transformation applying polynomials. The

characteristics and then further organised into object groups, and object groups into object entities. Thus, the vector data making a digital topographic model, saved as points, lines or polygons, systematically (thematically and according to the presentation manner) are organised into spatial layers, i.e. object entities. The object groups within larger object entities are designed on the basis of TK25 and by means of the collection of topographic symbols so that they can be identified on a map. The system of codes and additional attributes (descriptions, names and similar) are attached to the topographic contents for each object entity, groups and the object itself.

2.3. Digital image processing

Many techniques of image processing and analysis have been developed for the purpose of interpreting and obtaining as much information as possible from the images gathered by means of remote sensing. The selection of specific techniques or algorithms depends on the purpose of each individual project.

Table 1. Cartographic demands (Frančula et al., 1994)

Positional accuracy	
scale	± 0.2 mm at the scale
1:25 000	± 5 m
1:50 000	± 10 m
Ability of details to be recognised	
buildings in a city	2 m
paths	2 m
subordinate roads	5 m
small streams	5 m
main roads	10 m
building blocks	10 m

rectification is carried out without applying digital height model since it was the issue of plane area, and in this case the remaining errors can be neglected.

Table 1 gives the cartographic demands on positional accuracy, as well as the ability of details to be recognised in the estimation of the extent to which the measured data obtained by satellites are adequate for the production or updating of topographic maps.

2.2. Digitalization and database

The transformation of analogous sources into digital vector format is carried out by means of vectorization. Geocoded topographic map TK25 – Osijek(326)-4-3 is vectorized manually. According to the conceptual project STOKIS (Paj, 1995), the topographic objects are classified into object classes according to their

2.3.1. Resolution merge

The image Landsat TM with seven spectral channels and spatial resolution of 30 m was merged with the panchromatic image of high spatial resolution. The merging has been carried out according to the principal components method. Such a combination provides the best characteristics of both sensors resulting multispectral data of high resolution. These data are expected to yield better interpretation of linear and polygon objects being of interest for cartographic application.

2.3.2. Image enhancement

Filters are usually used for correction and renewal of images damaged by bad functioning of a system, for image enhancement for the purpose of visual interpretation and recognition of characteristics. In all

2. METODOLOGIJA

2.1. Geokodiranje

Izvorna topografska karta TK25 Osijek(326)-4-3 skanirana je s rezolucijom od 600 dpi. Prije geokodiranja rezolucija je smanjena na 400 dpi zbog obimnosti podataka. Postupak geokodiranja referentne podloge, tj. lista topografske karte proveden je na temelju trigonometrijskih točaka kao kontrolnih točaka.

Da bi se satelitski snimci mogli upotrijebiti za izradu ili

pohranjeni kao točke, linije ili poligoni, sustavno (tematski i prema načinu prikaza) organizirani u prostorne slojeve (layere), tj. objektna cjeline. Objektna grupe unutar većih objektnih cjelina oblikovane su na temelju TK25 i s pomoću topografskoga ključa, tako da se mogu lako identificirati na karti. Topografski sadržaj atributiziran je sustavom kodova i dodatnih atributa (opisa, naziva, i sl.) za svaku objektnu cjelinu, grupu i sam objekt.

2.3. Digitalna obrada snimaka

Tablica 1. Kartografski zahtjevi (Frančula i dr., 1994)

Položajna točnost	
mjerilo	$\pm 0,2$ mm u mjerilu
1:25 000	± 5 m
1:50 000	± 10 m
Raspoznatljivost detalja	
zgrade u gradu	2 m
staze	2 m
sporedne ceste	5 m
mali vodotoci	5 m
glavne ceste	10 m
blokovi zgrada	10 m

osuvremenjivanje karata također ih je nužno geokodirati, tj. prestrukturirati slikovne elemente tako da odgovaraju položaju u određenoj kartografskoj projekciji. Za transformaciju točaka između kartografske projekcije i satelitskog snimka primjenjuju se parametarska i neparametarska transformacija, ovisno o tome određuju li se u postupku transformacije parametri senzora ili ne. Najčešće je rješenje neparametarska transformacija primjenom polinomske transformacije. Rektifikacija je izvedena bez primjene digitalnog modela visina budući da je u pitanju ravninsko područje te je u tom slučaju pogreška rektifikacije satelitskih snimaka zanemariva.

Kako bi se ocijenilo u kojoj su mjeri podaci dobiveni satelitima prikladni za izradu i osuvremenjivanje topografskih karata, u tablici 1 dani su kartografski zahtjevi za položajnu točnost te raspoznatljivost detalja.

2.2. Digitalizacija i baza podataka

Pretvaranje analognih izvornika u digitalni, vektorski zapis provodi se postupkom digitalizacije, tj. vektorizacije. Geokodirana topografska karta TK25 – Osijek 43 (326-4-3) vektorizirana je ručno. Prema Idejnom projektu STOKIS-a (Paj, 1995), topografski se objekti u skladu sa svojim obilježjima razvrstavaju u objektnu vrstu, koje se dalje organiziraju u objektnu grupu, a objektnu grupu u objektnu cjelinu. Tako su vektorski podaci, koji čine digitalni topografski model,

Mnoge su tehnike obrade i analize snimaka razvijene radi interpretacije i dobivanja što je više moguće informacija iz snimaka prikupljenih daljinskim istraživanjima. Izbor specifičnih tehnika ili algoritama ovisi o svrsi svakog individualnog projekta.

2.3.1. Stapanje rezolucija

Snimak Landsat TM sa sedam spektralnih kanala i prostornom rezolucijom od 30 m spojen je s pankromatskim snimkom visoke prostorne rezolucije. Spajanje je izvedeno metodom svojstvenih komponenata. Takva kombinacija osigurava najbolje karakteristike obaju senzora, tako da su dobiveni visokorezolutni multispektralni podaci. Od tih se podataka očekuje bolja interpretacija linearnih i poligonskih objekata, koji su od interesa za kartografsku primjenu.

2.3.2. Pojašnjavanje snimaka

Filtri se obično upotrebljavaju za korekciju i obnavljanje snimaka oštećenih lošim funkcioniranjem sustava, za pojašnjavanje snimaka za vizualnu interpretaciju i izdvajanje značajki. Svrha je toga postupka, kao i svih postupaka prostornog pojašnjavanja, kreirati nove snimke iz izvornih slikovnih podataka, a time povećati količinu informacija koje mogu biti vizualno interpretirane (Javorović, 1994). Tehnike prostornog pojašnjavanja modificiraju vrijednosti piksela zasnovane na sivim vrijednostima



Slika 1. Isječak izvorne karte
Fig. 1. Part cut out from a source map

spatial enhancement procedures, the purpose is to create a new image from the source image data with increased information quantity that can be visually interpreted (Javorović, 1994). Techniques of spatial enhancement modify the values of pixel based on grey values of the surrounding pixels. They change the characteristics of spatial image frequencies by averaging the grey value within the defined window around the pixel that needs to be modified.

In order to have the image IRC-1C better interpreted, the “high-boost” filter or the filter with emphasised high frequencies (Viher, 1998), has been used here. This filter is applied when one wants to emphasise local change in a small environment of pixels, i.e. in the cases when one wants to detect and locate small objects and details on objects that possess very weak, but sudden change of intensity.

2.3.3. Image interpretation

Referring to the complexity of digital image data, the approach to their interpretation and analysis is very distinctive. Their basic division refers to visual and computer aided interpretation. Visual interpretation is significant in obtaining potential information that is saved in remote sensing data on the basis of human observation. The advantage of such (human) interpretation is the ability of recognising a context, texture and shape on the image. With the help of aerial photographs and on the basis of spectrally merged and filtered images the line objects have been visually interpreted and vectorized (traffic routes and water bodies being line objects in cartographic presentations).

The settlements can be digitized as points or as polygons. The image resolution leads us to the presentation of settlements as polygons so that a group of houses is turned into block by means of subjective generalisation. Such polygon presentation of settlements is not adequate to the presentation of

settlements on the topographic map at the scale of 1:25 000. Since the possibilities of updating the map in the above mentioned scale are being examined, we come to the conclusion that the stated image cannot be used for mapping the settlements at the scale of 1:25 000.

The detection of polygon objects, water bodies and vegetation has been left to the process of classification.

2.3.4 Classification

The goal of classification is to replace the visual analysis of image data by the methods for automating the scene characteristic identification. This includes the analysis of multispectral image data and the application of statistically based rules for the determination of land coverage identity for each scene pixel. The pixels are appointed to the classes. These classes can be connected with known characteristics of the terrain or they can only present the areas that look different to the computer algorithm.

For the classification of the merged multispectral image in the combination of panchromatic IRS-1C and multispectral Landsat TM intended for obtaining the data about vegetation there has been a repeated unsupervised classification applied. In the first iteration of ISODATA algorithm, the class means can be determined arbitrarily. After each iteration there is a new mean computed based on actual spectral locations of pixels in the group. These new means are then used for defining the groups of the next iteration. The process is continued up to minimum change among iterations (Erdas, 1997).

The contents of the map sheet Osijek(326)-4-3 was very demanding for the classification analysis. The most of the sheet is covered by the areas of the Nature Park *Kopački rit*, rich in biotic and hydrological structure. For cartographic purposes it was necessary to separate



Slika 2. Isječak istog područja s nadopunjenim novim sadržajem
 Fig. 2. Part cut out of the same area with supplemented new contents

okolnih piksela. One mijenjaju karakteristike prostornih frekvencija snimka usrednjavanjem sive vrijednosti unutar definiranog prozora oko piksela koji treba biti modificiran.

Zbog bolje interpretabilnosti snimka IRS-1C, ovdje je primijenjen *high-boost* filtar ili filtar s istaknutim visokim frekvencijama (Viher, 1998). Taj se filtar primjenjuje kada se želi istaknuti lokalna promjena na uskom okolišu piksela, tj. u slučajevima kada želimo otkriti i locirati sitne objekte i detalje na objektu koji imaju vrlo slabu, ali naglu promjenu intenziteta.

2.3.3. Interpretacija snimaka

S obzirom na kompleksnost digitalnih slikovnih podataka, pristupi njihovoj interpretaciji i analizi su različiti. Njihova se glavna podjela odnosi na vizualno i računalno podržanu interpretaciju. Vizualna interpretacija ima značenje dobivanja potencijalnih informacija koje su pohranjene u podacima daljinskih istraživanja na osnovi ljudskog zapažanja. Prednost je takve (ljudske) interpretacije prepoznavanje konteksta, teksture i oblika na snimci. Uz pomoć aerofotogrametrijskih snimaka, a na temelju spektralno spojenih i filtriranih snimaka vizualno su interpretirani i vektorizirani linijski objekti (prometnice i vode koje su u kartografskom prikazu linijski objekti).

Naselja je moguće digitalizirati kao točke, gdje bi bio digitaliziran svaki pojedini objekt, ili kao poligone. Rezolucija snimka navodi nas na prikaz naselja kao poligona tako da se skupine kuća subjektivnom generalizacijom pretvore u blokove. Takav poligonski prikaz naselja nije adekvatan prikazu naselja na topografskoj karti mjerila 1:25 000. S obzirom da se ispituju mogućnosti osuvremenjivanja karta navedenog mjerila, zaključujemo da se navedeni snimak ne može upotrijebiti za kartiranje naselja u mjerilu 1:25 000.

Detekcija poligonskih objekata, voda i vegetacije ostavljeno je procesu klasifikacije.

2.3.4. Klasifikacija

Svrha je klasifikacije snimaka zamijeniti vizualnu analizu slikovnih podataka s metodama za automatiziranje identifikacije značajki scene. To uključuje analizu multispektralnih slikovnih podataka i primjenu statistički zasnovanih pravila zaključivanja za određivanje identiteta zemljišnog pokrova svakog piksela scene. Pikseli se dodjeljuju klasama. Te klase mogu biti povezane s poznatim značajkama terena ili one mogu samo prikazati područja koja računalnom algoritmu izgledaju različita.

Za klasifikaciju spojenoga multispektralnog snimka kombinacije pankromatskog IRS-1C i multispektralnog Landsat TM u svrhu dobivanja podataka o vegetaciji višestruko je primijenjena nenadzirana klasifikacija. Za provođenje nenadzirane klasifikacije ERDAS IMAGINE rabi algoritam ISODATA koji upotrebljava formule minimalne spektralne udaljenosti za formiranje klasa. U prvoj iteraciji algoritma ISODATA, sredine klasa mogu biti otprilike određene. Nakon svake iteracije za svaku klasu se računa nova sredina zasnovana na aktualnim spektralnim lokacijama piksela u grupi. Tada se te nove sredine upotrebljavaju za definiranje grupa sljedeće iteracije. Proces se nastavlja do minimalne promjene među iteracijama (ERDAS, 1997).

Sadržaj ovog lista karte vrlo je zahtjevan za klasifikacijsku analizu. Većinu lista pokriva područje parka prirode *Kopački rit*, koje je bogato u biotopskoj i hidrološkoj strukturi. Za kartografske potrebe ovog lista bilo je potrebno odvojiti močvarno područje od šume i vodu. Pri klasifikaciji su primijenjeni svi spektralni kanali osim termalnoga. Nakon provedene početne nenadzirane klasifikacije, iz niza od 25 klasa izdvojene su potencijalne klase šume. Na tako izdvojenom području, a na osnovi spektralnih svojstava izabranoga šumskog područja definirane su dvije klase šume koje se uvode u nenadziranu klasifikaciju, kojom se izdvaja

the marshland from forests and water bodies. In the classification there have been all spectral channels applied except the thermal one. After the initial unsupervised classification has been carried out, the potential forest classes have been separated from the set of 25 classes. On thus separated area, and on the basis of new spectral properties of the selected forest area, there have been two forest classes defined that are introduced into the unsupervised classification separating ten new classes. Those classes that do not represent a forest have been abandoned, and the accuracy estimation for the other classes has been carried out running up to 87.5%. Three classes have been separated with their accuracy being unsatisfactory, and the area under these classes has undergone one more unsupervised classification. After selecting the classes, the accuracy of classification runs up to 91.1%. The references for determining the accuracy of classes have been the satellite image IRS-1C enhanced by means of a filter and aerial photographs.

The area of “clean” water has been separated by the unsupervised classification as well. The marshland is classified by a few classes, and on the basis of an image being a summer image in this case, with a lot of vegetation and obviously longer dry period, it was not possible to define it with certainty. Similarly, the polygons of water bodies cannot be defined on this image in a satisfactory manner.

3. CONCLUSIONS

On the basis of the research carried out about cartographic potential of panchromatic satellite image IRS-1C in combination with Landsat TM image used for updating the map at the scale of 1:25 000 we come to the following conclusions:

The majority of linear objects on maps at this scale can be identified again on the stated images. Worse paths cannot be completely identified, and pedestrian pavements and streams are impossible to be detected on the image of this resolution.

New line objects of the object group presenting road traffic up to the category of worse paths are easily identified (Fig. 1-3). Traffic, transport and communication objects cannot be identified.

The afore-mentioned image cannot be used for mapping the settlements at the scale of 1:25 000. Larger public and industrial surfaces can be identified.


Polygon objects of vegetation and water bodies are determined by means of classification. Forests and clean water are easily identified. The marshland is defined by several classes, and on the basis of one


image taken during the extensive vegetation and longer dry period it is impossible to identify it with certainty. It is recommended for such marshland to use images from various seasons in order to define the presence of water more accurately and to produce a *dynamic map*, or the map of changes. In order to obtain more accurate classification it would be necessary to have more verification in the field and to combine information.

Although the updating of topographic maps at the scale of 1:25 000 is not provided fully by the above stated methodology, the database was supplemented with a great quantity of data that can be further enriched by the usage of aerial photographs or satellite images of better resolution. Moreover, the database can be generalised and used for the production of a topographic map at some smaller scale than 1:25 000.

References

- Erdas (1997): Erdas Field Guide, Erdas Inc., Atlanta.
- Frančula, N., Lapaine, M., Vučetić, N. (1994): Primjena daljinskih istraživanja u kartografiji (Application of remote sensing in cartography, *in Croatian*), Geodetski list, 3, 265-276.
- Javorović, I., (1999): Erdas Imagine, Seminar theses (*in Croatian*), University of Zagreb, Faculty of Geodesy.
- Paj, R. (voditelj, 1995): Službeni topografsko-kartografski informacijski sustav, Idejni projekt, Državna geodetska uprava, (Official topographic and cartographic information system, A conceptual project, State Geodetic Administration, *in Croatian*), Zagreb.
- Viher, M. (1998): High-boost, filter for the emphasizing of higher frequencies, *in Croatian*, manuscript.





Slika 3. Satelitski snimak s prikazom novoga kartografskog sadržaja

Fig. 3. Satellite image with the presentation of new map contents

deset novih klasa. Odbačene su one klase koje ne predstavljaju šumu te je provedena ocjena točnosti za preostale klase, koja iznosi 87,5%. Izdvojene su tri klase kojih je točnost nezadovoljavajuća, pa je područje pod tim klasama provedeno kroz još jednu nenadziranu klasifikaciju. Nakon selekcije klasa, točnost klasifikacije odabranih klasa iznosi 91,11%. Referentna podloga za određivanje točnosti klasa je filtrom pojašnjen satelitski snimak IRS-1C i aerofotogrametrijski snimci.

Područje “čiste” vode izdvojeno je također nenadziranom klasifikacijom. Močvaru definira nekoliko klasa pa ju na osnovi jednog snimka, u ovom slučaju ljetnoga snimka, bujne vegetacije i očito dužega sušnog razdoblja, nije moguće sa sigurnošću definirati. Isto tako, poligoni vodenih površina ne mogu u potpunosti ponovno biti identificirani na tom snimku.

3. ZAKLJUČAK

Na osnovi provedenog istraživanja o kartografskom potencijalu pankromatskoga satelitskog snimka IRS-1C u kombinaciji sa snimkom Landsat TM, a za osuvremenjivanje karte mjerila 1:25 000 možemo zaključiti sljedeće:

- Većina linearnih objekata na kartama ovog mjerila može biti ponovno identificirana na navedenim snimcima. Lošije kolne putove nije moguće u potpunosti identificirati, a pješačke staze i potoke nemoguće je detektirati na snimku te rezolucije.
- Novi linijski objekti objektne grupe cestovnog prometa do kategorije lošijih kolnih putova lako se identificiraju (slike 1-3). Objekte za promet, transport i komunikacije nije moguće identificirati te se podaci preuzimaju s karte.

- Navedeni se snimak ne može upotrijebiti za kartiranja naselja u mjerilu 1:25 000. Veće javne i industrijske površine moguće je identificirati.

- Poligonski objekti vegetacije i vode određeni su klasifikacijom. Šuma i čista voda lako su identificirane. Močvaru definira nekoliko klasa pa ju na osnovi jednog snimka, bujne vegetacije i dužega sušnog razdoblja, nije moguće sa sigurnošću definirati. Za točnije definiranje prisutnosti vode na močvarnim područjima predlaže se upotreba snimaka iz različitih godišnjih doba i izvedba dinamičke karte, tj. karte promjena. Za točniju klasifikaciju potrebna je također veća zastupljenost verifikacije na terenu i udruživanje informacija.

Iako navedenom metodologijom nije u potpunosti osigurano osuvremenjivanje topografskih karata mjerila 1:25 000, baza je upotpunjena velikom količinom podataka, koji se dalje mogu nadograditi upotrebom aerofotogrametrijskih snimaka ili satelitskih snimaka bolje rezolucije, ili generalizirati i upotrijebiti za izvedbu topografske karte nekog sitnijeg mjerila od 1:25 000.

Literatura

- Erda Field Guide (1997): Erda Inc., Atlanta
- Frančula, N., Lapaine, M., Vučetić, N. (1994): Primjena daljinskih istraživanja u kartografiji, Geodetski list, 3, 265-276
- Javorović, I. (1999): Erda Imagine, seminarski rad, Geodetski fakultet, Zagreb
- Paj, R. (voditelj, 1995): Službeni topografsko-kartografski informacijski sustav, Idejni projekt, Državna geodetska uprava, Zagreb.
- Viher, M. (1998): High-boost, filter za isticanje visokih frekvencija, rukopis